

UNIVERSIDADE FEDERAL DE SÃO PAULO  
ESCOLA PAULISTA DE POLÍTICA ECONOMIA E NEGÓCIOS

NATHÁLIA RODRIGUES SANTOS

**REDES NEURAIS PARA A PREVISÃO DE PREÇOS DE ENERGIA NO  
MERCADO LIVRE BRASILEIRO**

OSASCO

2019

NATHÁLIA RODRIGUES SANTOS

REDES NEURAIIS PARA A PREVISÃO DE PREÇOS DE ENERGIA NO  
MERCADO LIVRE BRASILEIRO

Monografia apresentada à Universidade Federal São Paulo como requisito parcial para a obtenção do grau em Bacharel em Ciências Econômicas.

Orientador: Prof. Dr. Leandro dos Santos Maciel

Osasco - SP  
2019

Santos, Nathália Rodrigues

REDES NEURAIIS PARA A PREVISÃO DE PREÇOS DE ENERGIA  
NO MERCADO LIVRE BRASILEIRO/Nathália Rodrigues Santos – Osasco,  
2019.

53 f.

Trabalho de conclusão de curso (graduação em Ciências  
Econômicas) – Universidade Federal de São Paulo, Escola Paulista de  
Política, Economia e Negócios, 2019.

Orientador: Prof. Dr. Leandro dos Santos Maciel

*Neural networks for energy prices forecasting in the Brazilian  
market.*

1. Mercado de energia. 2. Previsão de preços. 3. Redes Neurais

## **AGRADECIMENTOS**

Desenvolver essa monografia é o último passo que dou no caminho longo e enriquecedor que foi a faculdade. E sem a participação de muitos, talvez eu não tivesse conseguido, dessa forma, não poderia deixar de agradecer às pessoas que considero indispensáveis para que essa jornada pudesse ser realizada.

À minha mãe, por todo o carinho e confiança, por me ouvir todas as noites, obrigada por ser o meu alicerce, me dando todo o suporte necessário para que eu me dedicasse inteiramente aos meus sonhos. Você é a minha guia, obrigada por me entender com os olhos, por toda a nossa conexão.

Ao meu pai, por todas as vezes que ele me trouxe na faculdade, por todas as vezes que ele me esperou a noite na porta de casa, por acreditar que eu fosse capaz de tudo.

À minha irmã, por todo o amor e parceria, a nossa união me inspira e me deu forças para crescer. Obrigada por ser atenciosa, justa, sensível, cuidadosa, dedicada, quero ser igual a você.

Às pessoas especiais que conheci e que tornaram esse caminho mais fácil e alegre. Enrico, por ser meu melhor amigo, meu companheiro, meu amor, por ser luz, felicidade e aconchego, por me apoiar e estar sempre comigo. Barbara, por ser a minha melhor amiga, por trilhar junto comigo o início, por abrir as portas da sua vida para mim, por tornar-se família. Agatha, por toda a nossa amizade, pelas inúmeras matérias que fizemos, por todas as feiras juntas, por ser minha parceira até no trabalho, por me dar abrigo quando eu mais precisei.

A toda minha família e amigos, eu não seria nada sem vocês.

Agradeço ao meu orientador, professor Leandro Maciel, pela orientação, revisões, incentivos, aprendizados e apoio durante o desenvolvimento deste trabalho.

Não podia deixar de agradecer as minhas primeiras mentoras, Cecília Lupatini e Isadora Carreiro, responsáveis por grande parte da profissional que me tornei. Vocês sempre terão um espaço de gratidão enorme no meu coração.

Por fim, gostaria de agradecer a UNIFESP, pelos encontros que ela me proporcionou, e pelo amadurecimento que ela me trouxe, hoje vejo o quanto cresci durante esses cinco anos e quanto esse ambiente foi responsável por isso.

## RESUMO

A energia elétrica é um insumo básico e essencial no mundo moderno. O Brasil se difere de países europeus devido a sua matriz energética com grande participação de fontes renováveis na geração de energia. Após a liberação do setor elétrico de energia no Brasil, a partir dos anos 90, e da separação das atividades de geração, transmissão, distribuição e comercialização de energia, atualmente, a contratação de energia no país está dividida em dois ambientes, o Ambiente de Contratação Regulada e o Ambiente de Contratação Livre. A presente monografia objetiva propor uma nova abordagem para a predição de preços de energia do Brasil, com base na utilização de modelos de Redes Neurais Artificiais (RNAs). Para isso, foram utilizados os dados de preços do sistema de livre negociação, no qual as cotações flutuam de acordo com as negociações entre os agentes, ou seja, com base na oferta e demanda. Os dados utilizados foram os Preços de Liquidação de Diferenças (PLD) no período desde maio de 2003 até julho de 2019. Como os preços são disponibilizados por submercados do sistema elétrico, foram consideradas quatro séries de preço de diferentes submercados: Sudeste, Sul, Norte e Nordeste. Os modelos competitivos de previsão, ARIMA, SARIMA, HoltWinters (HW) e RNA foram avaliados com base em diferentes métricas de erros para previsões um passo à frente e 19 passos à frente, representando curto e longo prazos, respectivamente. Em todas as regiões o modelo de RNA apresentou resultados mais acurados no curto prazo (um passo à frente), enquanto que no longo prazo (19 passos à frente), nenhum dos modelos resultou em bom ajuste. Entretanto, o modelo de suavização HW apresentou o melhor ajuste aos preços em alguns momentos com preços bem próximos aos reais quando as previsões de longo prazo são analisadas.

**Palavras chave:** Mercado de energia, previsão de preços, redes neurais.

## ABSTRACT

Electricity is a basic and essential resource in the modern world. Brazil differs from European countries due to its energy matrix with large participation of renewable sources in power generation. After the deregulation of the electric power sector in Brazil, since the 90's, and the separation of the activities of generation, transmission, distribution and commercialization of energy, the energy contracting in the country is divided in two environments, the Regulated Contracting and the Free Contracting Environment. This monograph aims to propose a new approach to the prediction of energy prices in Brazil, based on the use of Artificial Neural Networks models. To do so we used data from the free trade system, in which prices fluctuate according to the negotiations between agents, in other words, based on supply and demand. The data used were the Difference Settlement Prices (PLD) in the period from May 2003 to July 2019. As prices are available by submarkets of the electric system, we considered four different price series in four different regions: Southeast, South, North and Northeast. Competitive forecasting models, ARIMA, SARIMA, HoltWinters (HW) and ANN, were evaluated based on different error to forecast one-step ahead and 19 steps ahead, representing the short and long term respectively. In all regions the ANN model presented more accurate results in the short term (one-step ahead), although in the long term (19 steps ahead) none of the models had a good adjustment, however the HW model presented the best price adjustment at some times with prices very close to the real ones if we analyze the forecasts of the long term.

**Keywords:** Energy market, prediction of prices, neural networks

## SUMÁRIO

<b>1 INTRODUÇÃO .....</b>	<b>7</b>
1.1 OBJETIVOS .....	9
1.2 JUSTIFICATIVA E CONTRIBUIÇÕES .....	10
1.3 ORGANIZAÇÃO DO TRABALHO .....	12
<b>2 SETOR ELÉTRICO BRASILEIRO .....</b>	<b>13</b>
2.1 HISTÓRICO .....	13
2.2 O NOVO MODELO DO SETOR ELÉTRICO .....	15
<b>3 REVISÃO BIBLIOGRÁFICA.....</b>	<b>20</b>
<b>4 METODOLOGIA .....</b>	<b>24</b>
4.1 ARIMA.....	24
4.2 SARIMA.....	25
4.3 HOLT-WINTERS .....	25
4.4 REDES NEURAIS ARTIFICIAIS .....	26
4.5 MÉTRICAS DE AVALIAÇÃO.....	30
<b>5 RESULTADOS.....</b>	<b>32</b>
5.1 SUDESTE .....	33
5.2 SUL .....	35
5.3 NORTE.....	38
5.4 NORDESTE .....	41
<b>6 CONCLUSÕES .....</b>	<b>44</b>
<b>7 REFERÊNCIAS BIBLIOGRÁFICAS .....</b>	<b>46</b>

## LISTA DE FIGURAS

<b>Figura 1.</b> PLD mensais de janeiro de 2016 até dezembro de 2017 .....	9
<b>Figura 2.</b> Estrutura institucional do setor elétrico.....	16
<b>Figura 3.</b> Submercados de energia brasileiro).....	19
<b>Figura 4.</b> Rede com duas camadas intermediárias. ....	27
<b>Figura 5.</b> Valores reais e previstos pelos modelos ARIMA, SARIMA, HW e RNA para horizonte de 19 passos à frente na série de preços de energia no submercado Sudeste .....	35
<b>Figura 6.</b> Valores reais e previstos pelos modelos ARIMA, SARIMA, HW e RNA para horizonte de 19 passos à frente na série de preços de energia no submercado Sul .....	37
<b>Figura 7.</b> Valores reais e previstos pelos modelos ARIMA, SARIMA, HW e RNA para horizonte de 19 passos à frente na série de preços de energia no submercado Norte. ....	40
<b>Figura 8.</b> Valores reais e previstos pelos modelos ARIMA, SARIMA, HW e RNA para horizonte de 19 passos à frente na série de preços de energia no submercado Nordeste.....	43



## LISTA DE TABELAS

<b>Tabela 1.</b> HoltWinters Multiplicativo e Aditivo .....	26
<b>Tabela 2.</b> Métricas de avaliação dos modelos utilizados para a região Sudeste. ....	34
<b>Tabela 3.</b> Métricas de avaliação dos modelos utilizados para a região Sul. ....	36
<b>Tabela 4.</b> Métricas de avaliação dos modelos utilizados para a região Norte.....	39

## LISTA DE ABREVIATURAS E SIGLAS

ABRACEEL	Associação Brasileira dos Comercializadores de Energia
ACL	Ambiente de Contratação Livre
ACR	Ambiente de Contratação Regulada
ANEEL	Agência Nacional de Energia Elétrica
ASMAE	Administradora de Serviços ao Mercado Atacadista de Energia
ARIMA	Modelos Autorregresivos Integrados de Médias Móveis
BNDE	Banco Nacional de Desenvolvimento Econômico
CCEE	Câmara de Comercialização de Energia
CMSE	Comitê de Monitoramento do Setor Elétrico
CMO	Custo Marginal de Operação
CNPE	Conselho Nacional de Política Energética
EPE	Empresa de Pesquisa Energética
FAC	Função de Autocorrelação
FACP	Função de Autocorrelação Parciais
HW	Modelo de suavização HoltWinters
MAE	Mercado Atacadista de Energia
MAE	<i>Mean Absolute Error</i>
MAPE	<i>Mean Absolute Percentage Error</i>
MASE	<i>Mean Absolute Scaled Error</i>

MME	Ministério de Minas e Energia
PLD	Preços de Liquidação das Diferenças
PPT	Programa Prioritário de Termoeletricas
ONS	Operador Nacional do Sistema Elétrico
REVISE	Revisão Institucional do Setor Elétrico
RMSE	<i>Root Mean Square Error</i>
RNA	Rede Neural Artificial
SIN	Sistema Interligado Nacional

## 1 Introdução

Em 2018, segundo o Anuário Estatístico de Energia Elétrica de 2018 da Empresa de Pesquisa Energética (EPE), o Brasil foi o oitavo país em capacidade instalada de geração elétrica no mundo e o segundo em capacidade instalada de geração hidrelétrica, ficando nessa última fonte atrás apenas da China. A geração total de energia no Brasil em 2017 foi de quase 590 GWh, sendo aproximadamente 36% utilizado para consumo industrial e 29% para consumo residencial.

A energia elétrica é um insumo básico e essencial no mundo moderno e a sua utilização, a precificação da mesma, e a acuracidade da previsão desses preços impacta todos os setores da economia. A partir do início do século XX, a eletricidade passou a ter maior importância no contexto da evolução e crescimento das cidades. Desde então, o setor foi predominantemente estatal, até os anos 90, década que o país passou por um amplo processo de privatização no Brasil, incluindo o setor de energia. Este foi o início da reforma que se aproxima da atual conjuntura do setor elétrico brasileiro.

A reforma no mercado de energia elétrica foi instituída em 2004, com o novo modelo institucional do setor elétrico, que resultou na elevação dos riscos associados à contratação de energia, devido aos fatores que causam uma maior volatilidade dos preços de energia, tais como: a impossibilidade de armazenamento para a venda futura; a incerteza da demanda; o considerável tempo necessário para a expansão de geração a fim de atender o crescimento da demanda; o preço dos combustíveis; e, principalmente, a hidrologia, que é o fator mais preponderante na determinação do preço da energia do Brasil (GESEL, 2014).


O setor energético no Brasil difere de países europeus, no sentido de que o modelo estrangeiro se adequa a sistemas no qual grande parte do parque gerador provém de combustíveis fósseis, distinto do brasileiro que é caracterizado por uma maior participação de fontes renováveis na geração de

energia. Também, com base nos dados do Anuário Estatístico de Energia Elétrica de 2018 da Empresa de Pesquisa Energética (EPE), o parque gerador brasileiro é predominantemente hidroelétrico, sendo quase 64% da geração elétrica obtida por fonte hidráulica em 2017. Além disso, o crescimento da geração eólica foi de quase 545% de 2013 a 2017, sendo atualmente o parque eólico é responsável por mais de 7% da geração elétrica no país. Dadas essas especificidades, o setor elétrico brasileiro apresenta características singulares.

A contratação de energia no Brasil atualmente está dividida em dois ambientes, que funcionam simultaneamente, e são chamados de Mercado Cativo ou Ambiente de Contratação Regulada (ACR) e o Mercado Livre ou Ambiente de Contratação Livre (ACL) (EPE, 2018).

Para entender a variação dos preços, é utilizado como parâmetro o ambiente livre de contratação de energia, aonde os preços flutuam e as negociações são feitas de forma bilateral entre os agentes, diferentemente do ambiente regulado em que os preços são regulados pela Agência Nacional de Energia Elétrica (ANEEL). O mercado livre de energia elétrica é, também, um ambiente em que consumidores e fornecedores negociam as condições de energia, mas está disponível somente para empresas com demanda acima de 500 kW. Deve-se destacar que a classe industrial representa quase 90% do consumo livre de energia.

Segundo relatório anual de janeiro de 2018 da Associação Brasileira dos Comercializadores de Energia, a quantidade de empresas no ambiente livre de contratação de energia passou de 613 em 2003 para 5.495 em junho de 2018. Essa evolução do mercado livre proporcionou, em média, uma economia de 18% em relação ao mercado cativo, a opção tradicional dos consumidores. O faturamento em 2017 das comercializadoras de energia foi de R\$ 110 bilhões, e o país tinha quase 240 companhias habilitadas a comercializar energia nesse mercado (ABRACEEL, 2018).



**Figura 1.** PLD mensais de janeiro de 2016 até dezembro de 2017. O PLD é o Preço da Liquidação das Diferenças e determina os preços do mercado de curto prazo. Fonte: CCEE

Dada a considerável variabilidade dos preços da energia elétrica no Brasil, que pode ser vista na Figura 1, que mostra a variação dos preços nos quatro submercados brasileiros (Sul, Sudeste, Norte e Nordeste) de janeiro de 2016 até dezembro de 2017. A partir da Figura 1 fica evidente a ausência de um padrão entre os mesmos meses em anos diferentes, e uma grande variabilidade entre os submercados. Logo, em um sistema de livre negociação, a adequada previsão dos movimentos futuros dos preços mostra-se de elevada importância para os agentes que atuam nesse mercado, sobretudo na gestão de riscos.

## 1.1 Objetivos

Nesse contexto, este trabalho objetiva propor uma nova abordagem para predição dos preços de energia no Brasil, com base na utilização de modelos de redes neurais artificiais. Sendo assim, o objetivo deste trabalho consiste em avaliar o poder preditivo de redes neurais artificiais (*artificial neural networks*) para a previsão dos preços de energia no mercado brasileiro, uma vez que tais preços apresentam características como alta volatilidade,

sazonalidade e não linearidade, o que torna complexa a sua antecipação por meio de modelos tradicionais de predição de séries temporais.

Como objetivos específicos, será realizada a comparação dos resultados dos modelos de redes neurais artificiais com técnicas usuais de previsão, como os modelos ARIMA, SARIMA e de suavização exponencial Holt-Winters, no contexto da predição de preços de eletricidade, sobretudo para o mercado de energia do Brasil, que ainda carece de trabalhos na literatura. Os resultados das técnicas competitivas serão comparados em termos de acurácia para diferentes horizontes de previsão. Os dados considerados serão dos submercados do setor elétrico brasileiro Norte, Nordeste, Sul e Sudeste, os dados coletados são os Preços de Liquidação das Diferenças - PLDs mensais a partir de janeiro de 2001 até dezembro de 2017.

Além disso, é também objetivo específico desta monografia discutir o panorama do mercado de energia no Brasil, mostrando como as transformações do setor culminaram no modelo de negociação de preços atual, entender a formação dos preços neste ambiente, e avaliar a utilização da metodologia de redes neurais artificiais para a previsão de preços no mercado de energia. Para tanto, é necessário entender o mercado de energia do Brasil, suas peculiaridades, e quais são as principais variáveis que afetam na formação dos preços de energia, para que se então formule um modelo adequado de previsão.

Por fim, o desenvolvimento de ferramentas acuradas de previsão é essencial para o processo de tomada de decisões, na administração de riscos e na elaboração de estratégias de comercialização de energia, evidenciando assim a necessidade de testar técnicas alternativas, como a proposta na presente monografia.

## **1.2 Justificativa e contribuições**

O estudo da previsão de preços no mercado de energia é de fundamental importância dado que o setor elétrico, afeta todos os outros setores da economia, sendo a eletricidade um insumo essencial tanto para a produção quanto para as famílias. Ademais, os agentes do mercado de

energia usam a previsão dos preços para definir suas estratégias de contratação, de maneira a maximizar seus lucros, enquanto que, para os geradores, a antecipação dos preços possibilita a minimização de suas despesas. Dessa forma, dado a elevada volatilidade dos preços no Ambiente de Contratação Livre (ACL), mostra-se de grande importância a redução das incertezas para os agentes do setor por meio da acurada previsão das oscilações futuras dos preços.

Diferentemente dos combustíveis fósseis, a energia renovável sofre impacto direto por causa da instabilidade na sua produção, por que dependem de fatores aleatórios para que possam ser produzidas, desta forma, a capacidade de inferir sobre preço da energia é essencial para mitigar riscos. Como ainda não há na literatura, de acordo com o nosso conhecimento, estudos envolvendo a previsão de preços de energia no Brasil com modelos de redes neurais artificiais, mostra-se necessário analisar o desempenho de preditivo de tal técnica, uma vez que se trata de modelos com capacidade de aproximar adequadamente funções não lineares complexas e variantes no tempo.

Com isso, a presente monografia contribui com da literatura ao propor uma nova abordagem de previsão de preços de energia no Brasil, mais especificamente, ao se considerar os modelos de redes neurais artificiais. Essa abordagem ainda é pouco explorada na literatura associada à predição dos preços de energia e, tampouco, considerando uma avaliação empírica para o mercado elétrico brasileiro. Tais modelos de previsão podem ser utilizados como uma ferramenta de suporte no processo de tomada de decisões no setor de energia elétrica. Além disso, a adequação dos métodos de redes neurais artificiais ainda se mostra evidente ao se considerar o mercado de energia brasileiro, que, com uma matriz energética predominantemente hidráulica, apresenta características que tornam o mercado peculiar, sobretudo em análise de predição de preços.



### **1.3 Organização do trabalho**

Após essa breve introdução, a presente monografia está estruturada como segue. O Capítulo 2 apresenta uma análise histórica do mercado de energia no Brasil usando como referência, principalmente, as pesquisas bibliográficas e dados quantitativos sobre as condições do setor desde o início do processo de privatização na década de 90.

A revisão de literatura é descrita no Capítulo 3, e compreende os estudos sobre o uso das técnicas de previsão para preços nos mercados de energia, com destaque para a consideração de modelos de redes neurais.

No Capítulo 4 consta a metodologia adotada, incluindo a descrição dos modelos e as métricas de avaliação dos resultados. O Capítulo 5, em seguida, apresenta os dados considerados e discute os resultados das previsões dos distintos modelos. Por fim, as conclusões são apresentadas no Capítulo 6 e também as possíveis pesquisas para desenvolvimento futuro.

## **2 Setor elétrico brasileiro**

### **2.1 Histórico**

A análise do setor elétrico brasileiro pode ser dividida de acordo com três principais períodos: o início da produção elétrica, o setor elétrico estatal e o setor elétrico predominantemente privado.

O primeiro período se inicia no final do século XIX quando a eletricidade começou a ser produzida no Brasil. Apenas no início do século XX, com o desenvolvimento das cidades de São Paulo e Rio de Janeiro, ocorreram investimentos de capitais estrangeiros para a instalação de companhias de energia elétrica. No governo de Getúlio Vargas, em 1934, foi promulgado o Código das Águas, que assegurava ao poder público o controle rigoroso das concessionárias de energia elétrica, assim, o governo nacionalista buscava a regulamentação das atividades do setor. Todavia, tal código não foi suficiente para assegurar o atendimento de energia, que aumentou após a Segunda Guerra Mundial, e nos anos posteriores ocorreram diversas medidas de racionamento de energia elétrica.

Marcado pela forte intervenção do Estado, o segundo período iniciado em 1950, foi a era monopolística do setor, o governo criou empresas, agentes reguladores e financiou empreendimentos de geração elétrica. A partir dos anos, a participação do governo se torna mais ativa no setor: em 1952 foi fundado o Banco Nacional de Desenvolvimento Econômico (BNDE), que forneceu empréstimos a empresas para a geração elétrica; em 1960 houve a criação do Ministério de Minas e Energia; seguido da fundação de empresas como Furnas S.A e Centrais Elétricas Brasileiras S.A - Eletrobrás, com a criação da última, o governo visava centralizar o planejamento da operação e da administração dos recursos financeiros.

A partir dos anos 80, o setor elétrico se viu envolvido com dois processos que requeriam atenção e foco do governo, as obras da maior usina elétrica do mundo naquela época - Itaipu Binacional; e o programa Nuclear

Brasileiro. Em contrapartida, devido à escassez de crédito nacional e internacional, os outros investimentos em aumento da capacidade produtiva energética foram interrompidos.

O modelo estatizante estava em crise, em decorrência de sua ineficiência econômica tarifária (o próprio governo adotou uma política de compensação tarifária elétrica como combate à inflação), vulnerabilidade a adversidades, e dívida elevada. Além dos motivos citados acima, este processo também resultou da necessidade do governo em privatizar seus ativos para pagamento de dívidas e do interesse de grupos estrangeiros no mercado brasileiro, dessa forma observou-se a necessidade de reestruturação do modelo utilizado. Em 1988, foi criada a Revisão Institucional do Setor Elétrico – REVISE que foi fundamental para as grandes alterações do setor elétrico na década de 90 (FERREIRA, 2000)

O terceiro período se inicia no começo dos anos 90 e continua até hoje: em 1993 ocorreu o chamado marco inicial da liberalização do setor energético brasileiro e, durante o primeiro governo do presidente Fernando Henrique Cardoso, a formação de um novo modelo para o setor foi efetivada. O governo criou a Agência Nacional de Energia Elétrica (ANEEL), que é o agente regulador e fiscalizador do setor elétrico e, também, o Operador Nacional do Sistema Elétrico (ONS), responsável pela operação do Sistema Interligado Nacional – SIN. Nesse modelo, houve, também, a separação das atividades de geração, transmissão, distribuição e comercialização de energia introduzindo competição nas atividades com o objetivo de tornar o processo de geração e distribuição de energia mais eficiente e com menores custos.

Porém, o liberalismo de mercado não fez surgir os investimentos esperados, já que as empresas recém-privatizadas possuíam um alto grau de endividamento. Esse endividamento ocorreu devido às estratégias políticas do II Plano Nacional do Desenvolvimento – II PND, que faziam com que as empresas do setor elétrico absorvessem prejuízos para não repassarem aos consumidores. O resultado dessa sistemática foi um setor defasado que não atendia à demanda de energia. O governo federal lançou nos anos 2000 o Programa Prioritário de Termoelétricas – PPT, que previa a construção de 49

usinas termoeletricas que acrescentaria 15.000 MW ao sistema interligado. Porém, o programa não teve a adesão esperada e apenas 10 usinas foram postas em funcionamento, representando um acréscimo de apenas 1.527 MW (CUBEROS, 2008).

Associado a estes fatores, em 2001, a ausência de investimentos e chuvas, em um sistema fortemente dependente de hidroelétricas, forçou o governo a programar o racionamento, que atingiu quatro das cinco regiões brasileiras. A partir disso, foi criado o Comitê de Revitalização em 2002, cuja principal função era propor alternativas para promover a expansão do setor elétrico.

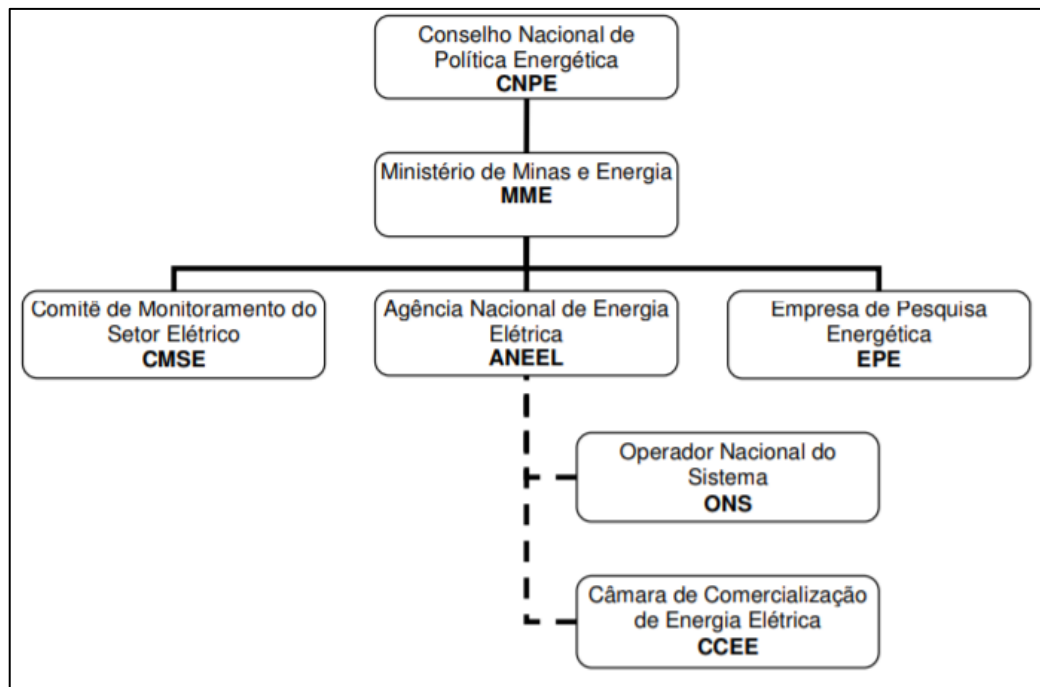
## **2.2 O novo modelo do setor elétrico**

Em março de 2004, o novo modelo do setor elétrico foi aprovado e suas principais premissas eram: promover a modicidade tarifária, estimulando a contratação eficiente de energia para consumidores regulados; garantir a segurança no suprimento de energia elétrica; estabilizar o mercado para atrair novos investidores; promover a inserção social, através de programas de universalização (CUBEROS, 2008).

Com objetivo de reestruturar o novo modelo do setor energético, novas instituições foram criadas, como a Empresa de Pesquisa Energética (EPE), o Comitê de Monitoramento do Setor Elétrico (CMSE), e outras redefinidas. Atualmente, a rede de instituições e agentes do Sistema Elétrico Brasileiro ficou distribuída da forma que é apresentada na Figura 2. Os agentes institucionais realizam atividades de três naturezas:

- Atividades de governo – Comissão Nacional de Política Energética (CNPE); Ministério de Minas e Energia (MME); Comitê de Monitoramento do Setor Elétrico (CMSE);
- Atividades regulatórias – Agência Nacional de Energia Elétrica (ANEEL);

- Atividades especiais – Empresa de Pesquisa Energética (EPE); Câmara de Comercialização de Energia (CCEE); Operador Nacional do Sistema Elétrico (ONS)



**Figura 2.** Estrutura institucional do setor elétrico. Fonte: Cuberos (2008).

O governo também criou a Câmara de Comercialização de Energia Elétrica (CCEE) que tem como objetivo administrar o Ambiente de Contratação Regulada (ACR) e o Ambiente de Contratação Livre (ACL), o qual é o provedor dos dados utilizados na presente monografia. Os participantes da CCEE são empresas que atuam no setor de energia elétrica nas áreas de geração, distribuição e comercialização, e suas principais atividades são: a realização de leilões de contratação de energia elétrica; registro dos contratos firmados entre compradores e vendedores; a contabilização de compra e venda de energia e a sua respectiva liquidação financeira e o monitoramento do mercado (MARQUES, 2015).

Em Sozzi (2018), o autor define os dois ambientes com as características a seguir: no Ambiente de Contratação Regulada (ACR) somente podem participar os geradores e empresas distribuidoras de energia elétrica. Neste ambiente, a compra e a venda de energia elétrica acontecem

através de leilões que têm como finalidade garantir o fornecimento de 100% da demanda de energia elétrica das distribuidoras.

E no Ambiente de Contratação Livre (ACL) podem operar os agentes de geração, comercialização e os consumidores livres e especiais. Nesse ambiente, os contratos de compra e venda são livremente negociados entre as partes com todas as condições comerciais como fornecedor, preço, quantidade de energia contratada, período de suprimento, pagamento, entre outras. A principal vantagem nesse ambiente é a possibilidade de contratar o que melhor atenda às expectativas de custo benefício.

O Mercado de Curto Prazo é o ambiente onde os agentes do ambiente de contratação livre (ACL) negociam a compra ou venda de energia para fecharem o balanço energético de suas empresas. Isso ocorre, pois, ao se fazer a contratação de energia elétrica, o agente faz apenas uma estimativa do consumo (*ex ante*). Sendo assim, pode existir uma diferença entre a energia contratada e a energia que foi consumida efetivamente pelo agente. Tal diferença deve ser liquidada no mercado de curto prazo e valorada ao Preço de Liquidação das Diferenças – PLD, que reflete o custo marginal atual de operação.

A Câmara de Comercialização de Energia Elétrica - CCEE foi criada em 2004 e tem como objetivo viabilizar a comercialização de energia elétrica no mercado de energia brasileiro (Lei nº 10.848, de 15 de março de 2004 e regulamentada pelo decreto Nº 5.177 de 12 de agosto de 2004). A partir da implementação de um novo modelo do setor elétrico foi necessário a reformulação das entidades que até então regulamentavam o mercado de curto prazo. Dessa forma, a CCEE começou a operar, sucedendo ao Mercado Atacadista de Energia (MAE) e a Administradora de Serviços ao Mercado Atacadista de Energia (ASMAE), visando garantir estabilidade, transparência e tranquilidade para o mercado de energia do país.

A CCEE contabiliza as operações de compra e venda de energia elétrica e determina os débitos e créditos dos agentes baseados no cálculo do Preço de Liquidação das Diferenças - PLD. No presente projeto de monografia,

o PLD medido pela CCEE será a nossa principal variável, pois este é o preço que permeia o mercado de curto prazo.

### 2.3 Preço de Liquidação de Diferenças (PLD)

A base para o cálculo do PLD é o Custo Marginal de Operação – CMO, calculado como o resultado de modelos matemáticos utilizados pelo Operador Nacional do Sistema Elétrico – ONS.

A cadeia de modelos NEWAVE (médio prazo) e DECOMP (curto prazo) fornece o CMO estabelece quanto custa produzir um MWh adicional para o sistema elétrico (CCEE, 2013).

O PLD considera os limites máximo e mínimo definidos anualmente pela ANEEL. O processo de precificação é definido por submercado (Sul, Sudeste, Nordeste e Norte), patamar de carga e semana, sendo definido atualmente de acordo com a seguinte expressão:

$$PLD_{S,T,W} = \min(\max(CMO\_SR\_EA_{S,T,W}, PLD\_MIN_{f^{PLD}}), PLD\_MAX_{f^{PLD}})$$

onde  $PLD_{S,T,W}$  é o Preço de Liquidação de Diferenças determinado por submercado “S”, patamar de carga “T” e semana “W”;  $CMO\_SR\_EA_{S,T,W}$  é o Custo Marginal de Operação Sem Restrição Ex-Ante por submercado “S”, patamar de carga “T” e semana “W”;  $PLD\_MIN_{f^{PLD}}$  é o valor mínimo que o PLD pode assumir para um determinado ano “ $f^{PLD}$ ”, compreendido entre a primeira e a última semana operativa de preços,  $PLD\_MAX_{f^{PLD}}$  é o valor máximo que o PLD pode assumir para um determinado ano “ $f^{PLD}$ ”, compreendido entre a primeira e a última semana operativa de preços (CCEE, 2013).

Atualmente o PLD é medido de forma semanal e é feito uma média ponderada mensal desses dados. Os agentes do setor e o governo buscam instituir o PLD horário que também é calculado e é subdividido por cada submercado, mas ainda não é utilizado no mercado livre de energia. Segundo o MME (2019) o PLD horário estava previsto para ser implantado a partir de 2020, no entanto o tema está em discussão, a viabilidade da implementação em 2020 é quase nula e busca-se a implantação definitiva em 2021.



**Figura 3.** Submercados de energia brasileiro. Fonte: Coelho (2017)

Na presente monografia considera-se o Preço de Liquidação das Diferenças Final Médio, que é determinado por mês, e por submercados do Sistema Interligado Nacional – SIN, sendo esses últimos representados na Figura 3.



### 3 Revisão bibliográfica

A energia elétrica tem grande valor na produção de um país, de modo que o impacto da previsão de preços de forma mais acurada auxilia o planejamento dos agentes que operam no setor, minimizando os custos e incertezas, com a consequente maximização dos lucros.

No Brasil, a matriz energética é predominantemente hidráulica e, como esta depende de fatores naturais, com baixa acuidade em termos de previsibilidade para a disponibilidade de recursos, os preços de energia elétrica variam significativamente. Ademais, fatores como a conjuntura econômica do país, a capacidade das linhas de transmissão entre as regiões, a geração eólica e a disponibilidade das termoeletricas são variáveis que demonstram a alta volatilidade do mercado. O preço da energia é, portanto, afetado por diversos fatores, o que implica em elevada volatilidade e não linearidades.

Os estudos sobre a previsibilidade de preços no setor energético no Brasil e no mundo apresentam distintos resultados de acordo com o mercado avaliado e os métodos de previsão considerados.

Amadeu (2011), por exemplo, avalia modelos de previsão para o preço de energia para o mercado brasileiro em que são examinados os desempenhos de técnicas de séries temporais, como modelos autorregressivos e modelos autorregressivos com regressores exógenos, assim como modelos não lineares de Rede Neurais Artificiais (RNAs). Os métodos foram testados com dados dos preços de energia no período de janeiro a setembro de 2011. O autor conclui que, apesar da simplicidade dos modelos autorregressivos, eles obtêm um bom desempenho se comparado aos demais, mas a capacidade de melhora dos modelos de redes neurais mostrou-se evidente, já que se observou menor erro geral entre todos os preditores.

Em Fiorin, Martins, Schuch, Pereira (2011), são testados as aplicações redes neurais artificiais na estimativa de recursos de energia solar, as redes de multicamadas foram utilizadas com sucesso para a modelagem de parâmetros

instantâneos de radiação solar e obtiveram ganhos significativos na previsão de parâmetros de radiação solar em relação aos modelos desenvolvidos a partir de regressão linear múltipla.

Também para o caso brasileiro, Reston Filho (2014) propõe uma nova abordagem híbrida para a previsão de preços de energia no mercado de curto prazo, que combina modelos autorregressivos integrados de médias móveis (ARIMA) e modelos de redes neurais. O modelo proposto considera uma previsão de 12 semanas à frente com a inclusão de variáveis explanatórias como a geração hidráulica, geração térmica, carga de energia, energia natural afluyente e energia armazenada. Os resultados obtidos com a metodologia híbrida apresentam uma boa exatidão quando comparadas com métodos de previsão *benchmarks* da literatura de séries temporais.

Para o mercado ibérico de eletricidade, Moreira (2015) avança no sentido de identificar o impacto de fatores externos no preço da eletricidade e, a partir disso, avalia o desempenho de vários modelos para prever os preços da eletricidade nesta região. Os dados consistiram no histórico dos preços da energia elétrica em Portugal e de informações de diversas variáveis, como o consumo de eletricidade, a produção de energia eólica, a velocidade do vento, a precipitação, a temperatura e a irradiação solar. Como no país a matriz energética é bem diversificada, o autor destaca a importância em se estudar diferentes variáveis para auxiliar na previsão dos preços. Os dados são relativos a cada uma das 24 horas do período compreendido entre 1 de janeiro de 2013 e 15 de setembro de 2014. Os resultados apontaram um elevado potencial do uso de métodos de regressão em quantis que, como uma metodologia simples, exigem um menor esforço computacional e produzem resultados estimados com maior interpretabilidade que métodos de redes neurais, por exemplo.

Em Oliveira (2016), foi realizada uma análise do problema de previsão de demanda de energia elétrica do Brasil, sendo a análise desse comportamento futuro fundamental para gerenciar as incertezas do mercado. O modelo RNA foi eficiente para previsão de demanda de energia elétrica considerando as o cenário brasileiro, utilizando as seguintes variáveis:

transporte, balanço energético, PIB anual, capacidade industrial, índices setoriais, população, SELIC, valor tarifário, clima, inflação, capacidade de geração, cotação do dólar, salário mínimo. Independente da inclusão de variáveis exógenas para previsão, os modelos apresentaram previsões adequadas para o cenário de demanda de energia elétrica brasileira que se desejava antecipar.

Croonenbroeck e Huttel (2017) analisaram o impacto na eficiência econômica de previsões imprecisas do mercado de energias renováveis. Para isso, eles utilizam um conjunto de dados de Alemanha e Áustria que contém médias horárias dos contratos negociados. Os resultados mostram que apesar de sofisticados, os modelos de previsão ainda precisam ser desenvolvidos para que a quantidade de erros diminua cada vez mais. Além disso, as previsões são mais imprecisas quanto maior o horizonte de análise.

No mercado da Bélgica, recentemente, Lago, Ridder e Schutter (2018), atestam a eficácia de métodos de *machine learning*, frente a métodos estatísticos, para a previsão de preços de energia, no período compreendido entre 1 de janeiro de 2010 até 31 de novembro de 2018. Os resultados mostraram que os métodos estatísticos sem entradas exógenas apresentaram baixa acuidade, enquanto que modelos de redes neurais com várias entradas forneceram um melhor desempenho.

A China tem uma grande política de expansão voltada a energia renovável, principalmente no setor eólico e solar, entretanto elaborar previsões objetivas sobre o preço da energia elétrica advinda de fontes renováveis é um desafio por causa da distribuição aleatória dos dados.

De acordo com o estudo de Wang, Zhenxing, Zhangb, Zhou e Peng (2019) é possível dividir os métodos de predição de preço de energia renovável em quatro grupos: métodos físicos, métodos estatísticos, técnicas de inteligência artificial e modelos híbridos. Dentre esses métodos, os físicos e os estatísticos se provaram mais eficientes na formulação de previsões para horizontes temporais longos, contudo, a inteligência artificial vem se provando mais eficiente nesse aspecto conforme vem sendo desenvolvida,

principalmente pelo fato de serem capazes de incorporar a relação não linear dos dados.

O estudo de Wang e Wang (2019) mostra resultados de grande precisão aplicando um modelo de rede neural híbrida para prever preços futuros de energia nos mercados globais, se comparado, por exemplo, a modelos como o SARIMA. O resultado evidencia que a rede neural apresenta menores desvios de erros ao prever os preços.

De forma geral, pode-se perceber que há inúmeros trabalhos que tratam da previsão dos preços de energia, não se verificando um consenso acerca da melhor técnica. Portanto, o estudo da antecipação de preços futuros mostra-se relevante, sobretudo quando a variável de interesse, preço de energia, afeta a tomada de decisão de inúmeros agentes em uma economia.

## 4 Metodologia

Para mensurar e avaliar o desempenho dos modelos de previsão para o mercado de energia, este capítulo apresenta a descrição das técnicas consideradas. Além disso, são apresentadas as medidas tradicionais de acurácia que serão consideradas para comparar os modelos de previsão competitivos. O desempenho das redes neurais artificiais será comparado com os obtidos por técnicas como os modelos ARIMA, SARIMA e Holt-Winters.

### 4.1 ARIMA

O modelo ARIMA - Autoregressivo Integrado de Médias Móveis, conhecido também como metodologia de Box-Jenkins, é próprio para análise e previsão de séries temporais. Esta abordagem consiste em ajustar modelos autoregressivos integrados de médias móveis a um conjunto de dados. Um modelo ARIMA (p,d,q), sendo (p,d,q) a representação da ordem do modelo, pode ser representado por:

$$\Delta^d Y_t = \mu + \phi_1 \Delta^d Y_{t-1} + \dots + \phi_p \Delta^d Y_{t-p} + \theta_1 \varepsilon_{t-1} + \dots + \theta_q \varepsilon_{t-q} + \varepsilon_t, \quad (1)$$

onde  $Y_t$  - série temporal analisada,  $\mu$  - média do processo,  $\phi_1$  e  $\phi_p$  - parâmetros AR;  $\theta_1$  e  $\theta_q$  - parâmetro MA,  $\Delta^d$  - número de diferenças para tornar a série estacionária, e  $\varepsilon_t$  um termo ruído branco.

Essa metodologia é uma das mais usadas para a análise de dados em séries temporais, pois ela pode lidar com séries estacionárias ou não, com ou sem elementos sazonais. Segundo Pindyck e Rubinfeld (2004), a aplicação do modelo ARIMA é composta de quatro etapas: identificação, estimação, verificação e previsão.

A identificação consiste em determinar os parâmetros (p,d,q) que melhor se ajustam à série temporal, para isso utiliza-se a interpretação dos correlogramas das funções de autocorrelação (FAC) e das funções de

autocorrelação parciais (FACP). Na etapa de estimação, realiza-se a obtenção estimativa dos parâmetros, via máxima verossimilhança. A verificação do modelo consiste em analisar se a estrutura escolhida descreve adequadamente o comportamento da série, ou seja, analisar se há parâmetros em excesso e se são significativos e, também, se os erros resultantes não são autocorrelacionados. A última etapa é a de previsão, que consiste em prever os valores futuros de uma série temporal com base no modelo identificado. (MORETTIN; TOLOI, 2004).

## 4.2 SARIMA

Os modelos SARIMA contemplam séries que apresentam autocorrelação sazonal, já que para séries não estacionárias no tempo, os modelos usuais ARIMA não são eficientes para reconhecer o padrão gerador da série sazonal. Nestes casos, para séries com padrões sazonais, modelos Sazonais ARIMA, ou simplesmente Modelos SARIMA, são mais apropriados (FADHILAH, IBRAHIM, 2012).

Um modelo SARIMA(p,d,q)-(P,D,Q) pode ser descrito como:

$$\Delta^d Y_t = \mu + \phi_1 \Delta^d Y_{t-1} + \dots + \phi_p \Delta^d Y_{t-p} + \theta_1 \varepsilon_{t-1} + \dots + \theta_q \varepsilon_{t-q} + (\rho_1 \Delta^D Y_{t-1S} + \dots + \rho_P \Delta^D Y_{t-PS} + \gamma_1 \varepsilon_{t-1S} + \dots + \gamma_Q \varepsilon_{t-QS}) + \varepsilon_t \quad (2)$$

Os modelos SARIMA combinam uma estrutura ARIMA com seus respectivos componentes sazonais, autoregressiva de ordem  $P$ , com número de diferenças sazonais de ordem  $D$  e de média móvel de ordem  $Q$ .

## 4.3 Holt-Winters

Nos estudos de Makridakis, Wheelwright e Hyndman (1998), afirma-se que o modelo Holt-Winters consiste em um método de suavização exponencial com ajuste de previsão para a sazonalidade. Este é um dos métodos mais utilizados para previsão de curto prazo, e envolve três equações que são associadas a cada uma das componentes do padrão de uma série de tempo:

nível, tendência e de sazonalidade, sendo esse último podendo ter efeito multiplicativo ou aditivo. As equações básicas para modelos de suavização Holt-Winters são apresentadas na Tabela 1.

**Tabela 1.** HoltWinters Multiplicativo e Aditivo

Componente	Holt-Winters Multiplicativo	Holt-Winters Aditivo
Nível	$L_t = \alpha \frac{Y_t}{S_{t-s}} + (1 - \alpha)(L_{t-1} + b_{t-1})$	$L_t = \alpha(Y_t - S_{t-s}) + (1 - \alpha)(L_{t-1} + b_{t-1})$
Tendência	$b_t = \beta(L_t - L_{t-1}) + (1 - \beta)b_{t-1}$	$b_t = \beta(L_t - L_{t-1}) + (1 - \beta)b_{t-1}$
Sazonalidade	$S_t = \gamma \frac{Y_t}{L_t} + (1 - \gamma)S_{t-s}$	$S_t = \gamma(Y_t - L_t) + (1 - \gamma)S_{t-s}$
Previsão	$F_{t+m} = (L_t + b_{t-m})S_{t-s+m}$	$F_{t+m} = L_t + b_{t-m} + S_{t-s+m}$

onde  $s$  - componente sazonal no tempo  $t$ ;  $L_t$  - nível da série;  $b_t$  - tendência;  $S_t$  - componente sazonal;  $F_{t+m}$  - previsão para o período  $m$  adiante;  $Y_t$  - valor observado;  $\alpha, \beta, \gamma$  - parâmetros exponenciais alisadores, do nível, da tendência e da sazonalidade, respectivamente.

O método aditivo é utilizado quando a amplitude da variação sazonal é constante com o passar do tempo. Já o método multiplicativo é utilizado quando a amplitude da variação sazonal aumenta com o passar do tempo.


#### 4.4 Redes Neurais Artificiais

As Redes Neurais Artificiais são sistemas paralelos distribuídos, compostos por unidades de processamentos simples que são chamadas de neurônios. Esses neurônios são dispostos em uma ou mais camadas com várias conexões, que são associadas a pesos. Nas RNAs, a solução de problemas passa por uma fase de aprendizagem, em que os dados do conjunto são utilizados posteriormente para gerar respostas para o problema.

As Redes Neurais Artificiais podem ter diferentes arquiteturas, sendo elas: *perceptron* de camada única e *perceptron* de múltiplas camadas. As

redes de camada única resolvem apenas problemas linearmente separáveis, e por isso foi necessário o desenvolvimento das redes multicamadas.

Uma RNA multicamadas (HAYKIN, 1999) é tipicamente composta de camadas alinhadas de neurônios. Nesse tipo de rede, as entradas são apresentadas na primeira camada, que é chamada camada de entrada. Essa camada distribui as informações para as camadas escondidas da rede. A última camada é a camada de saída, onde a solução do problema é obtida. A Figura 4 mostra um exemplo de RNA multicamadas.



**Figura 4.** Ilustração de rede neural com duas camadas intermediárias.

Uma das características mais importantes de uma RNA é a sua habilidade de aprender através de ajustes aplicados aos pesos. Este ajuste é realizado através de um algoritmo de aprendizado. Esse algoritmo consiste em um conjunto de regras bem definidas para resolver um problema de aprendizagem, esses algoritmos se diferem pela forma de ajuste de pesos. (MARTINELLI, 1999).

Existem três métodos básicos de aprendizados em RNAs: aprendizado supervisionado, o aprendizado é obtido através de um supervisor com o objetivo de ajustar os parâmetros da rede; aprendizado não supervisionado, a rede neural artificial extrai as características relevantes e cria padrões de



aprendizagem para as entradas; e aprendido por reforço, aprendido por tentativa e erro em que a rede é recompensada em caso de sucesso e punida em caso de fracasso.

Uma RNA pode ser definida como uma forma de mapear um número de entradas em um grupo de saídas (Pindyck e Rubinfeld, 2004). E em cada neurônio  $j$  da camada oculta existe uma entrada correspondente à soma ponderada representada por:

$$\sum_{i=0}^n w_{ji}x_i = w_{j0} + w_{j1}x_1 + w_{j2}x_2 + \dots + w_{jr}x_r \quad (4)$$

onde  $i$  é o índice do neurônio da camada de entrada;  $j$  é o índice do neurônio da camada de saída;  $w_{ji}$  são os pesos responsáveis pela construção da rede neural e  $x_i$  são as camadas de entrada.

O primeiro elemento ( $w_{j0}$ ) da soma pode ser definido como o "viés". Após essa soma ocorre a aplicação da função de ativação. A função de ativação é aquela que processa o sinal gerado pela combinação linear das entradas e dos pesos das sinapses, para gerar o sinal de saída do neurônio. Abaixo são apresentados os três tipos mais utilizados de função de ativação, o resultado da função ativação é representado por  $\sigma(x)$ . A função ativação utilizada no modelo de redes neurais artificiais da presente monografia é a função sigmoide.

- I. Função de limiar: quando o valor da função for negativo, a saída do neurônio é igual a zero e quando o valor for positivo a saída é igual a um.

$$\sigma(x) = \begin{cases} 1 & \text{se } x \geq 0 \\ 0 & \text{se } x < 0 \end{cases} \quad (5)$$

- II. Função de limiar por partes: esse tipo de função pode ser visto como uma aproximação de um amplificador não linear.

$$\sigma(x) = \begin{cases} 1 & \text{se } x \geq 0,5 \\ \frac{x}{2} & \text{se } -0,5 < x < 0,5 \\ 0 & \text{se } x \leq -0,5 \end{cases} \quad (6)$$

III. Função sigmoide: é o tipo de função de ativação mais utilizado em redes neurais artificiais. É definida como uma função crescente que apresenta um balanço entre o comportamento linear e não linear.

$$\sigma(x) = \frac{1}{1+e^x} \quad (7)$$

Os exemplos de aplicações mais conhecidos de RNAs geralmente envolvem algoritmos conhecidos como Regra Delta e BackPropagation que são utilizados para a determinação dos pesos.

A Regra Delta segue o modelo de aprendizado supervisionado e por correção de erro, ou seja, os ajustes dos pesos são efetuados de maneira a obter um erro mínimo, esse algoritmo só pode ser utilizado em RNAs sem camadas intermediárias. O ajuste dos pesos da camada de entrada é realizado através da Equação 8.

$$w_{ij}(t+1) = w_{ij}(t) + \eta x_i \delta_j \quad (8)$$

$$\delta_j = d_j - y_j \quad (9)$$

onde o erro  $\delta_j$  é calculado como a diferença entre a resposta desejada  $d_j$  e a resposta produzida  $y_j$  pela RNA. O  $w_{ij}(t)$  é o peso associado à entrada  $i$  do neurônio  $j$ ,  $\eta$  é a velocidade de aprendizagem e  $x_i$  é a entrada  $i$  do neurônio  $j$ .

O algoritmo de aprendizado utilizado para treinar RNAs com múltiplas camadas intermediárias é conhecido como BackPropagation. Neste algoritmo o ajuste de pesos é baseado na Regra Delta (Equação 8); porém, na camada de saída, o erro é calculado proporcionalmente à diferença entre a saída desejada e a saída produzida como apresentado na abaixo.

$$\delta_j = y_j(d_j - y_j) \quad (10)$$

Através das redes neurais é possível gerar previsões em uma abordagem não linear e que não requer nenhuma hipótese acerca da dinâmica dos dados.

#### 4.5 Métricas de avaliação

As previsões de preços do mercado de energia construídas no presente trabalho serão avaliadas de acordo com diferentes medidas de erro, sendo elas: *root mean square error* (RMSE), *mean absolute error* (MAE), *mean absolute percentage error* (MAPE), e *mean absolute scaled error* (MASE).

O RMSE, ou raiz do erro quadrático médio, é a medida mais frequentemente utilizada para comparar erros de previsão de diferentes modelos. Essa medida identifica o quão concentrado os dados estão da linha de melhor ajuste (valor real), de forma que, quanto menor for o valor do RMSE, melhor o ajuste (maior acurácia) e, se for igual à zero, indicaria um ajuste perfeito. Esta medida é calculada como:

$$RMSE = \sqrt{\frac{1}{T} \sum_{t=0}^T (x_t - y_t)^2} \quad (11)$$

onde  $y_t$  - valor previsto;  $x_t$  - valor real;  $T$  - número de previsões

O MAE, ou erro absoluto médio, mensura a magnitude média dos erros em um conjunto de previsões sem considerar sua direção, calculado como:

$$MAE = \frac{\sum_{t=1}^T |y_t - x_t|}{T} \quad (12)$$

onde  $|y_t - x_t|$  é o erro absoluto.

O MAPE, ou erro médio percentual absoluto, é uma medida de precisão usada como uma função de perda para problemas de regressão e na avaliação dos modelos preditivos, quanto menor for essa medida é melhor o ajuste do modelo. O MAE é calculado da seguinte forma:

$$MAPE = \frac{100}{T} \sum_{t=1}^T \left| \frac{x_t - y_t}{x_t} \right| \quad (13)$$

Por fim, o MASE, ou erro médio absoluto escalonado, é recomendado para determinar a precisão comparativa de previsões. São propriedades dessa medida: independência de escala, ou seja, podem ser usados para comparar séries diferentes; enquanto as medidas de precisão da previsão percentual, como o MAPE distorcem a distribuição para valores do conjunto que sejam próximos ou iguais à zero, essa medida não faz essa distorção; o erro médio absoluto em escala penaliza igualmente os erros positivos e negativos da previsão, e penaliza igualmente os erros nas previsões em longo prazo e em curto prazo. Quando menor for o valor dessa medida, melhor é o modelo, a fórmula da MASE está descrita abaixo:

$$MASE = \frac{\frac{1}{T} \sum_t |e_t|}{\frac{1}{T-1} \sum_{t=2}^T |x_t - x_{t-1}|} \quad (14)$$

onde  $e_t = x_t - y_t$  é o erro de previsão.

Essas são as medidas de erro que serão utilizadas para analisar os métodos de previsão avaliados nesse trabalho.

## 5 Resultados

Este capítulo apresenta os resultados da análise empírica a respeito do desempenho dos modelos utilizados no presente estudo. Estes foram avaliados de acordo com diferentes métricas que evidenciam o melhor modelo para prever os preços no curto e longo prazo. As variáveis de entrada escolhidas para os quatro modelos foram selecionadas através de testes, para ver qual mais se adequava e tinha uma melhor resposta para as métricas de erro.

Os dados utilizados nessa monografia consistirão nos Preços de Liquidação de Diferenças (PLD) que são os preços da energia do ambiente de contratação livre (ACL) disponibilizados mensalmente pela Câmara de Comercialização de Energia Elétrica no período desde maio de 2003 até julho de 2019.

Os conjuntos de previsão de preços foram definidos da seguinte forma: o conjunto “dentro” (*in-sample*) são os Preços de Liquidação de Diferenças dos meses de maio de 2003 até dezembro de 2017, em um total de 176 observações, que são utilizados como base para estimação dos modelos, o conjunto denominado “fora” (*out-of-sample*) são os Preços de Liquidação de Diferenças dos meses de janeiro de 2018 a julho de 2019, que foram utilizados para avaliar as previsões fora da amostra, com base em horizontes de um passo à frente e 19 passos à frente.

Os preços estão divididos por submercados, dessa forma, teremos quatro séries e resultados diferentes para cada submercado: Sudeste, Sul, Norte e Nordeste. Todas as análises foram realizadas usando o *software* R e o pacote *forecast*.

## 5.1 Sudeste

Para o modelo ARIMA na série de dados da região Sudeste foi escolhido os seguintes parâmetros: ARIMA (1,1,0); isso significa um modelo autoregressivo de primeira ordem, com uma ordem de diferenciação não sazonal e um termo constante. O modelo SARIMA não apresentou mudança com relação à sazonalidade, em decorrência disso o modelo selecionado foi: SARIMA (1,1,0)-(0,1,0)<sup>1</sup> utilizando as mesmas métricas que mais se adequaram no modelo ARIMA e uma diferença sazonal.

No modelo HW, utilizamos o modelo aditivo, e os parâmetros de nível, tendência e sazonalidade foram gerados pelo próprio modelo, também foi acrescentada a variável de suavização que apresentou resultados melhores para a série. E o modelo de Rede Neural Artificial é composto por duas defasagens, ou seja,  $y_{t-1}$  e  $y_{t-2}$  para prever  $y_t$ ; uma defasagem sazonal, quatro camadas intermediárias; e 300 repetições, cada repetição é inicializar os pesos das redes de forma aleatória diferente e permite um resultado mais acurado.


---

<sup>1</sup> No modelo SARIMA as variáveis (P, D, Q) foram escolhidas como (0,1,0), entretanto foram testados diversos valores para essas variáveis e nenhum conjunto apresentou mudança de resultado se comparado ao modelo ARIMA.

**Tabela 2.** Métricas de avaliação dos modelos utilizados para a região Sudeste.

<b>Sudeste</b>				
<b>Dentro</b>	<i>RMSE</i>	<i>MAE</i>	<i>MAPE</i>	<i>MASE</i>
<i>ARIMA</i>	85,789	46,924	<b>39,375</b>	0,999
<i>SARIMA</i>	85,789	46,924	<b>39,375</b>	0,999
<i>HW</i>	84,342	49,565	64,237	<b>0,331</b>
<i>RNA</i>	<b>75,905</b>	<b>46,037</b>	48,038	0,980
<b>1 passo à frente</b>	<i>RMSE</i>	<i>MAE</i>	<i>MAPE</i>	<i>MASE</i>
<i>ARIMA</i>	123,260	95,926	<b>46,699</b>	0,955
<i>SARIMA</i>	123,260	95,926	<b>46,699</b>	0,955
<i>HW</i>	124,054	98,834	47,117	<b>0,550</b>
<i>RNA</i>	<b>113,020</b>	<b>96,301</b>	51,110	0,959
<b>19 passos à frente</b>	<i>RMSE</i>	<i>MAE</i>	<i>MAPE</i>	<i>MASE</i>
<i>ARIMA</i>	146,623	120,278	59,995	2,560
<i>SARIMA</i>	146,623	120,278	59,995	2,560
<i>HW</i>	<b>146,440</b>	<b>118,602</b>	<b>59,527</b>	<b>2,524</b>
<i>RNA</i>	148,663	132,258	77,161	2,815

Nas previsões feitas com os dados do conjunto de dentro da amostra o modelo RNA obteve melhor resultado nas medidas RMSE com o valor 10 pontos mais baixo que as outras medidas de erro. O MAE também apresenta o melhor resultado para o modelo RNA, já o menor resultado no MAPE dentro da amostra foi obtido nos modelos ARIMA e SARIMA e o MASE foi menor na amostra para o modelo HW. Para o conjunto de fora da amostra os resultados para as métricas de erro foram os mesmos do conjunto dentro e nas previsões 19 passos o modelo Holt-Winters obteve o melhor resultado em todas as medidas de erro.



**Figura 5.** Valores reais e previstos pelos modelos ARIMA<sup>2</sup>, SARIMA, HW e RNA para horizonte de 19 passos à frente na série de preços de energia no submercado Sudeste.

Os preços previstos no horizonte de 19 passos à frente pelos quatro modelos estão plotados na Figura 5, nenhum dos quatro modelos se aproxima das tendências dos preços reais. Os modelos ARIMA e SARIMA apresentam os mesmos valores durante toda a previsão 19 passos à frente, R\$ 239,03. Os modelos HW e RNA apresentaram diferentes variações, mas não conseguiram acompanhar as elevações e as quedas dos preços, a média de variação foi menor no modelo HoltWinters, dessa forma, ele foi o modelo que mais se ajustou aos preços reais do Sudeste.

## 5.2 Sul

Para o modelo ARIMA na série de dados da região Sul foi escolhido os seguintes parâmetros: ARIMA (0,1,1); isso significa um modelo autoregressivo com uma ordem de diferenciação não sazonal e um termo constante. O modelo SARIMA, assim como na região Sudeste, não apresentou mudança

<sup>2</sup> Os preços previstos pelos modelos ARIMA e SARIMA foram os mesmos, dessa forma os valores previstos no modelo SARIMA sobrepõe os preços previstos do modelo ARIMA e estes não ficam visíveis na figura 5.



com relação à sazonalidade, em decorrência disso o modelo selecionado foi: SARIMA (0,1,1) (0,1,0)<sup>3</sup> utilizando as mesmas métricas que mais se adequaram no modelo ARIMA e uma diferença sazonal.

No modelo HW utilizamos o modelo aditivo e os parâmetros de nível, tendência e sazonalidade foram gerados pelo próprio modelo, também foi acrescentado a variável de suavização que apresentou resultados melhores para a série. E o modelo de Rede Neural Artificial é composto por três defasagens, ou seja,  $y_{t-1}$ ;  $y_{t-2}$  e  $y_{t-3}$  para prever  $y_t$ ; uma defasagem sazonal; três camadas intermediárias; e 300 repetições.


**Tabela 3.** Métricas de avaliação dos modelos utilizados para a região Sul.

<b>Sul</b>				
<b>Dentro</b>	<i>RMSE</i>	<i>MAE</i>	<i>MAPE</i>	<i>MASE</i>
<i>ARIMA</i>	91,888	48,841	<b>54,004</b>	1,011
<i>SARIMA</i>	91,888	48,841	<b>54,004</b>	1,011
<i>HW</i>	87,959	51,297	88,365	<b>0,402</b>
<i>RNA</i>	<b>76,372</b>	<b>45,187</b>	62,617	0,935
<b>1 passo à frente</b>	<i>RMSE</i>	<i>MAE</i>	<i>MAPE</i>	<i>MASE</i>
<i>ARIMA</i>	126,360	101,623	50,675	1,011
<i>SARIMA</i>	126,360	101,623	50,675	1,011
<i>HW</i>	<b>117,690</b>	<b>92,558</b>	<b>45,443</b>	<b>0,514</b>
<i>RNA</i>	120,162	108,893	56,161	1,083
<b>19 passos à frente</b>	<i>RMSE</i>	<i>MAE</i>	<i>MAPE</i>	<i>MASE</i>
<i>ARIMA</i>	<b>145,973</b>	<b>128,644</b>	<b>71,405</b>	<b>2,663</b>
<i>SARIMA</i>	<b>145,973</b>	<b>128,644</b>	<b>71,405</b>	<b>2,663</b>
<i>HW</i>	154,084	133,475	71,947	2,763
<i>RNA</i>	151,145	137,086	81,440	2,837

Analisando as métricas dos modelos utilizadas especificamente para a região Sul observamos que para os dentro da amostra o RNA obteve os

<sup>3</sup> No modelo SARIMA as variáveis (P, D, Q) foram escolhidas como (0,1,0), entretanto foram testados diversos valores para essas variáveis e nenhum conjunto apresentou mudança de resultado se comparado ao modelo ARIMA.

melhores resultados com relação aos demais levando em consideração o RMSE e MAE, tendo se distanciado consideravelmente dos demais, sendo aproximadamente 13,17% menor do que o resultado obtido através do HW que foi o segundo melhor resultado RMSE, já o MAE a diferença entre a segunda melhor estimativa não foi tão significativa quanto o do RMSE e foi de apenas 6,79%. Entretanto nas demais medidas de erro os modelos ARIMA, SARIMA e HW apresentaram resultados mais satisfatórios do que o do RNA, por uma margem considerável. Para a amostra de fora o modelo HW apresentou o menor erro em todos os casos, o que nos indica que foi modelo que melhor se adequou a série original. E por fim na previsão de 19 passos os modelos que melhor se adequaram foram os ARIMA e SARIMA, contudo, a diferença deles para os demais foi baixa.



**Figura 6.** Valores reais e previstos pelos modelos ARIMA<sup>4</sup>, SARIMA, HW e RNA para horizonte de 19 passos à frente na série de preços de energia no submercado Sul.

Na Figura 6, é possível verificar que os modelos ARIMA e SARIMA apresentam os mesmos valores de R\$270,34 durante toda a previsão 19 passos à frente. No curto prazo, de janeiro de 2018 a março de 2018, o modelo

<sup>4</sup> Os preços previstos pelos modelos ARIMA e SARIMA foram os mesmos, dessa forma os valores previstos no modelo SARIMA sobrepõe os preços previstos do modelo ARIMA e estes não ficam visíveis na figura 6.

RNA segue a tendência de elevação dos preços reais, porém a partir de então o modelo passa a ter um valor próximo aos 300 reais com pequenas variações. O modelo HW apresentou a menor média de variância dos preços em todo o período com enquanto as Redes Neurais apresentou variação maior como é possível perceber nos gráficos, porém nenhum modelo apresentou tendência aproximada no longo prazo.

### 5.3 Norte

Na região Norte para o modelo ARIMA foi escolhido os seguintes parâmetros: ARIMA (0,1,0); isso significa um modelo autoregressivo estacionário com uma ordem de diferenciação não sazonal e sem termo constante, este modelo pode ser considerado um *random walk*, ou seja, um modelo mais simples de passeio aleatório. O modelo SARIMA, assim como nas outras regiões não apresentou mudança com relação à sazonalidade, em decorrência disso o modelo selecionado foi: SARIMA (0,1,0) (0, 1, 0)<sup>5</sup> utilizando as mesmas métricas que mais se adequaram no modelo ARIMA e uma diferença sazonal.

Para o Norte, assim como nas regiões Sudeste e Sul, no modelo HW utilizamos o modelo aditivo e os parâmetros de nível, tendência e sazonalidade que foram gerados pelo próprio modelo, porém não foi acrescentada a variável de suavização, o modelo apresentou melhor acurácia sem a suavização. Já o modelo de Rede Neural Artificial é composto por três defasagens, ou seja,  $y_{t-1}$ ;  $y_{t-2}$  e  $y_{t-3}$  para prever  $y_t$ ; uma defasagem sazonal; quatro camadas intermediárias; e 300 repetições, este modelo apresentou melhor ajuste.

---

<sup>5</sup> No modelo SARIMA as variáveis (P, D, Q) foram escolhidas como (0,1,0), entretanto foram testados diversos valores para essas variáveis e nenhum conjunto apresentou mudança de resultado se comparado ao modelo ARIMA.


**Tabela 4.** Métricas de avaliação dos modelos utilizados para a região Norte.

<b>Norte</b>				
<b>Dentro</b>	<i>RMSE</i>	<i>MAE</i>	<i>MAPE</i>	<i>MASE</i>
<i>ARIMA</i>	82,319	47,178	<b>71,521</b>	0,995
<i>SARIMA</i>	82,319	47,178	<b>71,521</b>	0,995
<i>HW</i>	80,332	50,464	104,751	<b>0,376</b>
<i>RNA</i>	<b>60,205</b>	<b>38,363</b>	80,010	0,809
<b>1 passo à frente</b>	<i>RMSE</i>	<i>MAE</i>	<i>MAPE</i>	<i>MASE</i>
<i>ARIMA</i>	<b>99,026</b>	<b>63,703</b>	50,187	0,947
<i>SARIMA</i>	<b>99,026</b>	<b>63,703</b>	50,187	0,947
<i>HW</i>	117,276	83,656	70,631	<b>0,665</b>
<i>RNA</i>	108,967	74,303	<b>48,216</b>	1,105
<b>19 passos à frente</b>	<i>RMSE</i>	<i>MAE</i>	<i>MAPE</i>	<i>MASE</i>
<i>ARIMA</i>	179,165	167,084	219,400	3,525
<i>SARIMA</i>	179,165	167,084	219,400	3,525
<i>HW</i>	<b>154,135</b>	<b>129,609</b>	<b>140,649</b>	<b>2,734</b>
<i>RNA</i>	173,457	159,447	202,292	3,363

Para a região Norte, o modelo de RNA apresentou um melhor resultado nas medidas de RMSE nas previsões dentro da amostra sendo 25,05% menor do que o resultado de HW e 26,86% menor do que os modelos ARIMA e SARIMA. No MAE o resultado também foi significativo para o modelo RNA foi 23,97% menor do que o modelo HW e 18,68% mais baixo do que os modelos ARIMA e SARIMA. Também para a o conjunto dentro da amostra, o resultado do MAPE foi melhor para os modelos autoregressivos e o modelo HoltWinters apresentou melhor desempenho de MASE.

Na amostra fora, os resultados foram diferentes, o RMSE e o MAE foram melhores nos modelos autoregressivos por uma diferença de mais de 8 pontos se comparado ao modelo de Redes Neurais. O MASE foi mais acurado no modelo HW; e o MAPE foi mais de 31% menor no modelo RNA do que no modelo de HoltWinters. Para os preços 19 passos à frente, o modelo HW

apresentou os resultados mais ajustados em todas as métricas de erro, sendo assim obteve o melhor desempenho nesse conjunto.



**Figura 7.** Valores reais e previstos pelos modelos ARIMA<sup>6</sup>, SARIMA, HW e RNA para horizonte de 19 passos à frente na série de preços de energia no submercado Norte.

Assim como nas outras regiões os modelos ARIMA e SARIMA apresentam os mesmos valores durante toda a previsão 19 passos à frente, R\$233,27. No curto prazo, de janeiro de 2018 a março de 2018, o modelo RNA segue a tendência de queda dos preços reais, porém a partir de então o modelo passa a ter um valor próximo aos 300 reais com pequenas variações. O modelo HW apresentou a menor média de variância dos preços em todo o período com preços bem próximos nos meses de maio de 2018 e julho de 2019.

<sup>6</sup> Os preços previstos pelos modelos ARIMA e SARIMA foram os mesmos, dessa forma os valores previstos no modelo SARIMA sobrepõe os preços previstos do modelo ARIMA e estes não ficam visíveis na figura 6.

## 5.4 Nordeste

O Nordeste seguiu os mesmos parâmetros do Norte: ARIMA (0,1,0); isso significa um modelo autoregressivo estacionário com uma ordem de diferenciação não sazonal e sem termo constante, este modelo pode ser considerado um *random walk*, ou seja, um modelo mais simples de passeio aleatório. O modelo SARIMA, assim como nas outras regiões não apresentou mudança com relação à sazonalidade, em decorrência disso o modelo selecionado foi: SARIMA (0,1,0) (0, 1, 0)<sup>7</sup> utilizando as mesmas métricas que mais se adequaram no modelo ARIMA e uma diferença sazonal.

Para o Nordeste no modelo HW utilizamos o modelo aditivo e os parâmetros de nível, tendência e sazonalidade que foram gerados pelo próprio modelo, porém não foi acrescentada a variável de suavização, o modelo apresentou melhor acurácia sem a suavização, assim como o Norte. E o modelo de Rede Neural Artificial é composto por duas defasagens, ou seja,  $y_{t-1}$  e  $y_{t-2}$  para prever  $y_t$ ; uma defasagem sazonal, quatro camadas intermediárias; e 300 repetições.

---


<sup>7</sup> No modelo SARIMA as variáveis (P, D, Q) foram escolhidas como (0,1,0), entretanto foram testados diversos valores para essas variáveis e nenhum conjunto apresentou mudança de resultado se comparado ao modelo ARIMA.

**Tabela 5.** Métricas de avaliação dos modelos utilizados para a região Nordeste.

Nordeste				
<b>Dentro</b>	<i>RMSE</i>	<i>MAE</i>	<i>MAPE</i>	<i>MASE</i>
<i>ARIMA</i>	88,285	49,541	<b>68,556</b>	0,995
<i>SARIMA</i>	88,285	49,541	<b>68,556</b>	0,995
<i>HW</i>	86,857	54,217	110,191	<b>0,346</b>
<i>RNA</i>	<b>76,009</b>	<b>47,628</b>	72,064	0,957
<b>1 passo à frente</b>	<i>RMSE</i>	<i>MAE</i>	<i>MAPE</i>	<i>MASE</i>
<i>ARIMA</i>	96,531	<b>70,028</b>	49,987	0,947
<i>SARIMA</i>	96,531	<b>70,028</b>	49,987	0,947
<i>HW</i>	102,445	78,445	<b>54,194</b>	<b>0,504</b>
<i>RNA</i>	<b>93,764</b>	77,605	58,749	1,050
<b>19 passos à frente</b>	<i>RMSE</i>	<i>MAE</i>	<i>MAPE</i>	<i>MASE</i>
<i>ARIMA</i>	152,413	129,594	107,734	2,603
<i>SARIMA</i>	152,413	129,594	107,734	2,603
<i>HW</i>	<b>152,162</b>	<b>119,623</b>	<b>90,806</b>	<b>2,403</b>
<i>RNA</i>	165,400	150,617	138,561	3,026

Nas previsões feitas com os dados do conjunto de dentro da amostra o modelo RNA obteve melhor resultado nas medidas RMSE com o valor 10 pontos mais baixo que as outras medidas de erro. O MAE também apresenta o melhor resultado para o modelo RNA, já o menor resultado no MAPE dentro da amostra foi obtido nos modelos ARIMA e SARIMA e o MASE foi menor na amostra para o modelo HW. Para a amostra fora, o RMSE foi melhor no modelo de Redes Neurais Artificiais, no MAE os modelos ARIMA e SARIMA apresentaram melhor ajuste e nos índices MAPE e MASE o modelo HoltWinters obteve melhores resultados.

Assim como nas outras regiões, para os preços 19 passos à frente, o modelo HW apresentou os resultados mais ajustados em todas as métricas de erro, sendo assim obteve o melhor acurácia.



**Figura 8.** Valores reais e previstos pelos modelos ARIMA<sup>8</sup>, SARIMA, HW e RNA para horizonte de 19 passos à frente na série de preços de energia no submercado Nordeste.

Na figura 8 temos os preços previstos para o horizonte de 19 passos à frente plotados para os quatro modelos, como em todas as regiões os modelos ARIMA e SARIMA apresentaram o mesmo valor, R\$ 234,20 durante todos os meses. No curto prazo, de janeiro de 2018 a março de 2018, o modelo RNA segue a tendência de elevação dos preços reais, porém a partir de então o modelo passa a ter um valor próximo aos 300 reais com pequenas variações. O modelo HW em certos momentos como em dezembro de 2018 para janeiro de 2019 mostra a tendência correta de queda nos preços e o valor bem próximo ao real em março de 2018 com diferença de apenas R\$0,87 e em julho de 2019 com diferença de R\$0,64, nos meses de maio e outubro de 2018, fevereiro e março de 2019 os preços previstos também foram próximos aos preços reais.

<sup>8</sup> Os preços previstos pelos modelos ARIMA e SARIMA foram os mesmos, dessa forma os valores previstos no modelo SARIMA sobrepõe os preços previstos do modelo ARIMA e estes não ficam visíveis na figura 6.



## 6 Conclusões

A previsão dos preços do mercado de energia é um tema relevante para os brasileiros, dado que o setor elétrico, afeta todos os outros setores da economia. Devido a significativa volatilidade e a elevação dos riscos associados à contratação de energia, a possível previsão de preços mais adequada aos reais apresenta ganhos para os setores. A presente monografia utilizou como parâmetro o ambiente livre de contratação de energia, aonde os preços flutuam e as negociações são feitas de forma bilateral entre os agentes.

Nesta monografia estudou-se modelos para a previsão de preços de energia no Brasil com modelos ARIMA, SARIMA, de HoltWinters, e de Redes Neurais Artificiais, com isso, o trabalho contribui com da literatura ao propor uma nova abordagem de previsão de preços de energia no Brasil. Para isso foi explicado o panorama do mercado de energia do Brasil, as transformações regulatórias do setor e as principais variáveis que afetam na formação dos preços de energia.

Para mensurar e avaliar o desempenho dos modelos de previsão para o mercado de energia foram considerados os modelos ARIMA, SARIMA, HoltWinters e Redes Neurais Artificiais. Esses modelos foram avaliados de acordo com as medidas de erro tradicionais de acurácia sendo elas: *root mean square error* (RMSE), *mean absolute error* (MAE), *mean absolute percentage error* (MAPE), e *mean absolute scaled error* (MASE).

As métricas de erros apresentam diferentes resultados para as regiões e para os modelos. No conjunto dentro em todas as regiões os resultados das métricas de avaliação foram diversos o RNA apresentou os melhores resultados para RMSE e MAE, o ARIMA e SARIMA se ajustaram ao MAPE e o HW foi mais positivo para o MASE. No conjunto fora não houve uma congruência dos resultados, sendo que cada região obteve o melhor resultado em um modelo diferente. E nos 19 passos à frente, o modelo HW foi o mais ajustado em todas as medidas de erro nas regiões, tendo assim, o melhor resultado entre os modelos.

No conjunto 19 passos à frente, todas as regiões o modelo de Redes Neurais Artificiais apresentou resultados mais satisfatórios no curto prazo, acompanhando a tendência de elevação ou queda dos preços reais. No longo prazo, nenhum dos modelos foi realmente eficiente, já que as previsões são feitas utilizando os preços que foram previstos, ou seja, contendo erros de previsão. Todavia, comparando os modelos, o HoltWinters apresentou o melhor ajuste aos preços no longo prazo, em alguns momentos com preços bem próximos aos reais.

Algumas questões devem ser levadas em consideração como limitações desse trabalho, como não considerar variáveis exógenas que são extremamente relevantes para a formação do preço, assim como a limitação de alguns modelos em incluir essas variáveis. Como sugestão para futuros estudos, seria interessar testar a inclusão de variáveis como a hidrologia prevista e a carga prevista para testar o desempenho dos modelos HoltWinters e Redes Neurais Artificiais que apresentaram melhor ajuste a estimação de preços.

## 7 Referências bibliográficas

Associação Brasileira dos Comercializadores de Energia Elétrica (ABRACEEL). **Relatório anual de energia de 2017**. Distrito Federal, 2018.

AMADEU, Jefferson Rampazo. **Desenvolvimento de Modelos para a Previsão de *Spread* do Preço de Energia Elétrica no Mercado de Curto Prazo**. Monografia (Graduação) – Escola de Engenharia de São Carlos, Universidade de São Paulo, São Carlos, 2011.

CCEE. **O Processo de Comercialização**. Desenvolvido por Câmara de Comercialização de Energia Elétrica, Brasília, 2011.

CCEE. **Formação de Preço de Liquidação das Diferenças (PLD)**. Desenvolvido por Câmara de Comercialização de Energia Elétrica, Brasília, 2011.

CCEE. **Preço de liquidação de diferenças**. Desenvolvido por Câmara de Comercialização de Energia Elétrica, Brasília, 2013.

COELHO, R. **O que é o PLD – Preço de Liquidação das Diferenças?** GRUGREEN, Florianópolis, 2017. Disponível < <http://grugreen.eng.br/o-que-e-o-pld-preco-de-liquidacao-das-diferencas/>>; acesso em 20 de outubro de 2019.

CROONENBROECK, Carsten; HUTTEL, Silke. **Quantifying the economic efficiency impact of inaccurate renewable energy price forecasts**. Universidade de Rostock. Energy, 134, pp. 767-774, 2017.

CUBEROS, Fábio Luiz. **Novo modelo institucional do setor elétrico brasileiro: análise dos mecanismos de mitigação de riscos de mercado das distribuidoras**. Dissertação (Mestrado em Sistemas de Potência) - Escola Politécnica, Universidade de São Paulo, São Paulo, 2008.

FABER, Pedro Henrique Hecksher. **Previsão de valores de ações utilizando deep-learning**. Trabalho (Graduação em Engenharia de Controle e

Automação) Publicação FT.TG-n. 07 – Faculdade de Tecnologia, Universidade de Brasília, Brasília, 2016.

FADHILAH, Yusof; IBRAHIM, Lawal Kane. **Modeling Monthly Rainfall Time Series Using ETS State Space and SARIMA Models**. International Journal of Current Research. v.4, ed.09: p195-200, 2012.

FERREIRA, Carlos Kawall Leal. **Privatização do setor elétrico no Brasil**. In: PINHEIRO, Armando Castelar; FUKASAKU, Kiichiro (Ed.). A privatização no Brasil: o caso dos serviços de utilidade pública. Rio de Janeiro: Banco Nacional de Desenvolvimento Econômico e Social, 2000. p. 179-220.

FIORIN, Daniel. V.; MARTINS, Fernando R; SCHUCH, Nelson J; PEREIRA, Enio B. **Aplicações de redes neurais e previsões de disponibilidade de recursos energéticos solares**. Rev. Bras. Ensino Fís., São Paulo , v. 33, n. 1, p. 01-20, Mar. 2011 .

HAYKIN, Simon. **Redes neurais artificiais: princípios e práticas**. Trad. Paulo Martins Engel, 2º ed. Bokman, Porto Alegre, 2001.

MAKRIDAKIS, Spyros; WHEELWRIGHT, Steve; HYNDMAN, Rob. **Manual of Forecasting: methods and applications**. 3. ed. [S. l.]: John Wiley & Sons. Inc., 1998.

MARTINELLI, Edmar. **Extração de conhecimento de Redes Neurais Artificiais**. Dissertação (Mestrado), Instituto de Ciências Matemáticas e de Computação da Universidade de São Paulo - São Carlos, 1999.

MME. **Preço Horário: implementação é aprovada**. Assessoria de Comunicação Social. PORTARIA Nº 300, DE 31 DE JULHO DE 2019 e PORTARIA Nº 301, DE 31 DE JULHO DE 2019. Ministério de Minas e Energia, Brasília - DF, 2019.

MOREIRA, Rui Felipe Costa. **Previsão Probabilística dos Preços de Energia Elétrica do Mercado Ibérico de Eletricidade**. Tese de Mestrado em Modelação, Análise de Dados e Sistema de Apoio à Decisão. Faculdade de Economia, Universidade do Porto. Porto, 2015.

MORETTIN, Pedro Alberto; TOLOI, Clelia Maria de Castro. **Análise de Séries Temporais**. Editora Edgard Blücher LtdaS, 535 pp. São Paulo, 2004.

OLIVEIRA, Evandro Lopes. **Previsão de demanda de energia elétrica com redes neurais artificiais e análise por série de Fourier**. Dissertação apresentada ao Programa de Pós-Graduação em Engenharia Elétrica - Universidade Federal de Minas Gerais, 2016.

PINDYCK, Robert; RUBINFELD, Daniel. **Econometria: modelos & previsões**. 3. ed. Rio de Janeiro: Elsevier, 2004.

RESTON FILHO, José Carlos **Previsão Multi-Passos a Frente do Preço de Energia Elétrica de Curto Prazo no Mercado Brasileiro**. Tese de Doutorado. Universidade Federal do Pará, 85pp. Pará, 2014.

RIDDER, Fjo; LAGO, Jesus; SCHUTTER, Bart. **Forecasting spot electricity prices: Deep learning approaches and empirical comparison of traditional algorithms**. Applied Energy, Volume 229, pp. 1286, 2018.

SOZZI, G. **Formação do preço da energia convencional nas transações entre agentes no mercado de curto prazo brasileiro**. Dissertação (Mestrado) – Escola Politécnica da Universidade de São Paulo. São Paulo, 2015.

WANG, Bin. WANG, Jun. **Energy futures prices forecasting by novel DPFWR neural network and DS-CID evaluation**. Neurocomputing, Volume 338, pp. 1-15. China, 2019.

WANG, Huaizhi; ZHENXING, Lei; ZHANG, Xian; ZHOU, Bin. PENG, Jianchun. **A review of deep learning for renewable energy forecasting**. Energy Conversion and Management, Volume 198, 2019.